

VŠB – Technická univerzita Ostrava  
Fakulta elektrotechniky a informatiky  
Katedra informatiky

Rozpoznání pohlaví za pomoci obrazů  
Gender Recognition Based on Image Analysis

2017

Miroslav Šuráb

## Zadání bakalářské práce

Student:

**Miroslav Šuráb**

Studijní program:

B2647 Informační a komunikační technologie

Studijní obor:

2612R025 Informatika a výpočetní technika

Téma:

Rozpoznání pohlaví za pomoci obrazů  
Gender Recognition Based on Image Analysis

Jazyk vypracování:

čeština

Zásady pro vypracování:

Rozpoznání konkrétní osoby za pomoci kamerových systémů je v posledních letech hodně rozvíjené téma. Aplikace tohoto druhu může být použita například v oblasti bezpečnosti a v boji proti nebezpečným útočníkům. Rozpoznání pohlaví může sloužit jako dílčí krok k následnému zpřesnění a urychlení celého rozpoznávacího procesu.

1. Popište základní pojmy a metody v oblasti příznakového rozpoznávání obličejů v obrazech.
2. Nastudujte oblast rozpoznávání pohlaví v obrazech.
3. Prozkoumejte vhodnost příznakových metod pro řešení zadaného problému.
4. Seznamte se s knihovnou OpenCV a popište jaké možnosti tato knihovna nabízí v dané oblasti.
5. S pomocí knihovny OpenCV vytvořte vybraný rozpoznávač.
6. Experimentálně ověřte funkčnost, přesnost a rychlost navrženého řešení na renomovaných datasetech.
7. Své závěry řádně zdokumentujte v textu práce.

Seznam doporučené odborné literatury:

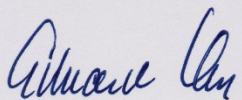
- [1] Zhao, W., Chellappa, R., Phillips, P., and Rosenfeld, A.: Face recognition: A literature survey. ACM Computing Surveys (CSUR), pp. 399-458 (2003)
- [2] Liao, S., Zhu, X., Lei, Z., Zhang, L., Li, S.Z.: Learning multi-scale block local binary patterns for face recognition. In: ICB. pp. 828-837 (2007)

Formální náležitosti a rozsah bakalářské práce stanoví pokyny pro vypracování zveřejněné na webových stránkách fakulty.

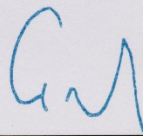
Vedoucí bakalářské práce: **Ing. Radovan Fusek, Ph.D.**

Datum zadání: 01.09.2016

Datum odevzdání: 28.04.2017



doc. Dr. Ing. Eduard Sojka  
vedoucí katedry



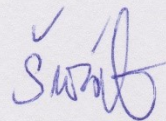
prof. RNDr. Václav Snášel, CSc.  
děkan fakulty



## Prehlásenie študenta

Prehlasujem, že som túto bakalársku prácu vypracoval samostatne. Uviedol som všetky literárne  
pramene a publikácie, z ktorých som čerpal.

V Ostrave Dňa: 26.04.2017



.....  
Podpis

## **Pod'akovanie**

Rád by som poďakoval vedúcemu bakalárskej práce Ing. Radovan Fusek, Ph.D. za odbornú pomoc a konzultáciu pri vytváraní tejto bakalárskej práce.

## **Abstrakt**

Cieľom tejto bakalárskej práce je predstaviť proces rozpoznávania pohlaví v obrazoch, objasniť základné pojmy v oblasti rozpoznávania tvárí a pohlaví, popísať bežne používané metódy, či spôsoby riešení v tomto odvetví a priblížiť použitie softvérovej knižnice OpenCV zameranej na spracovanie obrazu. Zároveň si berie za dôraz priblížiť proces takéhoto spracovania a načrtnúť isté teoretické poznatky, ktoré sú v tomto odvetví významné a prakticky použiteľné. Práca bližšie predstavuje spôsob rozpoznávania pohlaví v obrazoch pomocou troch konvenčne využívaných metód Eigenfaces, Fisherfaces a Local Binary Patterns Histograms. Problematika metód je popísaná vo svojom rozsahu teoretickou časťou, vlastným návrhom, implementáciou a funkčným testovaním. Vytvorené riešenia, doplnené testovaním poskytujú funkčný základ pre prácu s rozpoznávaním pohlaví v obrazoch. Výsledky tejto práce môžu byť kvalitným základom pri ďalších testovaniach, či ďalšom vývoji v tejto oblasti.

## **Kľúčové slová**

rozpoznávanie pohlaví, detekcia, pohlavie, OpenCV , spracovanie obrazu, analýza obrazu, obraz, Eigenfaces, Fisherfaces, LBPH, LBP, LDA, PCA, Haar, Cascade, klasifikácia pohlavia, rozpoznávanie tvárí, testovanie

## **Abstract**

The point of this bachelor thesis is to present process of gender recognition based on image analysis, describe basic terms in the field of gender and face recognition, describe commonly used methods or ways of solutions within this field and to specify use of software library OpenCV which is focused on image analysis. At the same time it tries to specify this process and describes certain theoretical knowledge significant for this field and practically usable. Thesis specifies way of gender recognition in images by means of the three conventionally used methods: Eigenfaces, Fisherfaces and Local Binary Patterns Histograms. The issues of these methods are defined by theoretical part, personal proposal, implementation and functional testing. Created and tested solutions are function basis for activity in the area of gender recognition. Results of this thesis may be a quality basis for further testing or further developement in this field.

## **Key Words**

gender recognition, detection, gender, OpenCV, image processing, image analysis, image, Eigenfaces, Fisherfaces, LBPH, LBP, LDA, PCA, Haar, Cascade, gender classification, face recognition, testing

# Obsah

Zoznam použitých symbolov a skratiek.....	9
Zoznam ilustrácií a tabuliek.....	10
1 Úvod.....	11
2 Teoretický rozbor.....	12
2.1 Rozdelenie metód rozpoznávania tvárí.....	14
2.2 Metóda Principal Component Analysis - PCA.....	16
2.3 Metóda Linear Discriminant Analysis - LDA.....	17
2.4 Metóda Local Binary Patterns - LBP.....	18
2.5 Rozpoznávanie pohlaví v obrazoch a metódy.....	18
2.6 Metóda Eigenfaces.....	20
2.7 Metóda Fisherfaces.....	21
2.8 Metóda Local Binary Patterns Histograms.....	23
3 Vlastná implementácia a testovanie.....	26
3.1 Príprava dát a implementácia.....	26
3.2 Testovanie a vstupy.....	30
3.3 Výsledky testovania Eigenfaces.....	31
3.4 Výsledky testovania Fisherfaces.....	32
3.5 Výsledky testovania Local Binary Patterns Histograms.....	33
3.6 Zhodnotenie výsledkov.....	34
4 Záver.....	37

# Zoznam použitých symbolov a skratiek

2D	dvoj-dimenzionálny rozmer
3D	troj-dimenzionálny rozmer
AT&T	databáza tvárí AT&T Laboratories-Cambridge
BSD	typ voľnej softvérovej licenci
C++	programovací jazyk
CSV	jednoduchý súborový formát vo forme čistého textu
FFS	Fusion of facial strips – metóda rozpoznávania pohlaví pomocou segmentácie obrazu
FLD	Fisher's Linear Discriminant – matematická metóda, ktorú popísal Sir Ronald Fisher
FRT	Facial recognition technology – technológia pomocou, ktorej je možné realizovať rozpoznávanie tvárí
Haar	typ kaskádového klasifikátoru, ktorý poskytuje knižnica OpenCV
LBP	Local Binary Patterns - patrí medzi metódy zamerané na extrakciu príznakov
LBPH	Local Binary Patterns Histograms – jedna z metód používaná k rozpoznávaniu, často využívaná v OpenCV, v princípe histogramy vyextrahované z obrazu spracovaného pomocou LBP
LDA	Linear Discriminant Analysis – metódy založené na rozdielnosti typov poskytnutých dát, využíva sa v metóde Fisherfaces
MB-LBP	Multi-scale Block Local Binary Patterns – varianta metódy LBP
OpenCV	multiplatformná knižnica zameraná najmä na počítačové videnie a spracovanie obrazu v reálnom čase
PCA	Principal Component Analysis – metóda analýzy, využíva sa v metóde Eigenfaces
PGM	formát obrazového súboru
Sada1	vstupná tréningová sada 1 – podmnožina databázi AT&T Laboratories Cambridge
Sada2	vstupná tréningová sada 2 – podmnožina databázi Extended Yale Face Database B
SVM	Support Vector Machines – metóda rozpoznávania v obrazoch
Test1	vstupný testovací súbor 1 – priaznivé podmienky
Test2	vstupný testovací súbor 2 – nepriaznivé podmienky
YaleB	databáza tvárí Extended Yale Face Database B



## **Zoznam ilustrácií a tabuliek**

- Obrázok 1 – Využitie rozpoznávania v kamerových záznamoch (str. 12)
- Obrázok 2 – Proces rozpoznávania tváre (str. 13)
- Obrázok 3 – Geometrické body tváre (str. 14)
- Obrázok 4 – Vývojový diagram algoritmu holistickej metódy Eigenfaces (str. 15)
- Obrázok 5 – Redukcia priestoru pomocou PCA (str. 17)
- Obrázok 6 – Rozdielnosť redukcie pomocou LDA oproti redukcii pomocou PCA (str. 17)
- Obrázok 7 – Spracovanie pixelov pomocou metódy LBP (str. 18)
- Obrázok 8 – Normalizácia a segmentácia tváre pomocou metódy FFS (str. 19)
- Obrázok 9 – Príklad eigenfaces vytvorených pod AT&T Laboratories Cambridge (str. 21)
- Obrázok 10 – Príklad výstupu spracovaných záznamov Fisherfaces (str. 23)
- Obrázok 11 – Princíp variability susedstiev v Extended LBP (str. 24)
- Obrázok 12 – Spracovanie obrazu pomocou LBP a výstupný histogram (str. 25)
- Obrázok 13 – Výsledok nesprávnych nastavení v metóde detectMultiScale (str. 29)
- Obrázok 14 – Vstupný obraz k rozpoznávaniu, priaznivé podmienky, Test1 (str. 30)
- Obrázok 15 – Vstupný obraz k rozpoznávaniu, nepriaznivé podmienky, Test2 (str. 30)
- Obrázok 16 – Percentuálna úspešnosť metódy Eigenfaces, tréningová Sada1 (str. 31)
- Obrázok 17 – Percentuálna úspešnosť metódy Eigenfaces, tréningová Sada2 (str. 32)
- Obrázok 18 – Percentuálna úspešnosť metódy Fisherfaces, tréningová Sada1 (str. 32)
- Obrázok 19 – Percentuálna úspešnosť metódy Fisherfaces, tréningová Sada2 (str. 33)
- Obrázok 20 – Percentuálna úspešnosť metódy LBPH, tréningová Sada1 (str. 33)
- Obrázok 21 – Percentuálna úspešnosť metódy LBPH, tréningová Sada2 (str. 34)
- Obrázok 22 – Výstup metódy Fisherfaces pre testovací obraz Test1 (str. 35)
- Obrázok 23 – Výstup metódy LBPH pre testovací obraz Test2 (str. 35)
- Tabuľka 1 – Hodnoty parametrov metódy detectMultiScale pre testovanie (str. 31)

# 1 Úvod

Detekcia pohlavia z obrazových záznamov (statického obrazu, či videa) môže mať zásadný význam v rôznych odvetviach, kde je potrebné určiť, rozoznať konkrétnu osobu. Určenie pohlavia vie z veľkej časti zúžiť zoznam hľadaných osôb a zjednodušiť tým určenie konkrétnej osoby. Svojím spôsobom je teda určenie pohlavia istým medzi-krokom pri identifikácii osoby.

Pre ľudí je takýto proces rozpoznávania prirodzený a pohlavie vieme väčšinou presne odhadnúť v rádoch sekúnd, avšak pri počítačovej technike je tento problém oveľa komplexnejší. Celý proces zahŕňa spracovanie obrazu na rôznych úrovniach (prevody, úpravy obrazu a podobne), ktoré zabezpečujú špeciálne navrhnuté algoritmy. Tieto algoritmy v sebe utvárajú istý spôsob ako sa učiť rozpoznávať jednotlivé objekty na základe istých kritérií a získaných dát obrazu.

Podstatou práce je popísať tieto algoritmy, zhodnotiť ich klady a zápory, priblížiť ich využitie a spôsoby spracovania obrazu a posúdiť ich odhad na základe vstupných parametrov. Účinným nástrojom k praktickej realizácii bude knižnica OpenCV, ktorá obsahuje kvalitné nástroje pre spracovanie obrazu a využíva pokročilé rozpoznávacie algoritmy.

Jednotlivé kapitoly práce sa ďalej venujú teoretickému rozboru problematiky rozpoznávania tváří a pohlaví a v druhom rade praktickej realizácii popísaných metód a ich testovaniu na renomovaných datasetoch.

## 2 Teoretický rozbor

Jedno z úspešných použití analýzy obrazu v posledných rokoch je práve odvetvie rozpoznávanie tvárí v obrazoch. Tento stav je spôsobený najmä širokým využitím na komerčné (príklad Obrázok 1), či právne účely a dostupnými realizovateľnými technológiami, postupmi vyvinutými v posledných rokoch výskumu. Komerčné a právne využívané aplikácie systémov pre rozpoznávanie tvárí (Face Recognition Technology - ďalej FRT) zahŕňajú v sebe rozsah od presne formátovaných fotografií až po nekontrolované video záznamy, kde je potrebné široké spektrum techník ako sú napríklad spracovanie obrazu, analýza, rozpoznávanie vzorov a ďalšie.

Všeobecne vieme rozdeliť tieto FRT systémy na dve skupiny a zároveň tie, ktoré pracujú so statickým obrazom a tie, ktoré pracujú s video záznamom. Medzi týmito skupinami existujú malé rozdiely, ktoré vyplývajú z ich konkrétneho použitia a sú to najmä kvalita obrazu, kritéria a parametre rozpoznávania, variabilita obrazu (tvary, sklon, uhol pohľadu a iné), pozadie obrazu (nehľadaná časť), správne definované rozpoznávanie, množstvo a škála vstupov a mnoho ďalších. Prevzaté podľa [1].

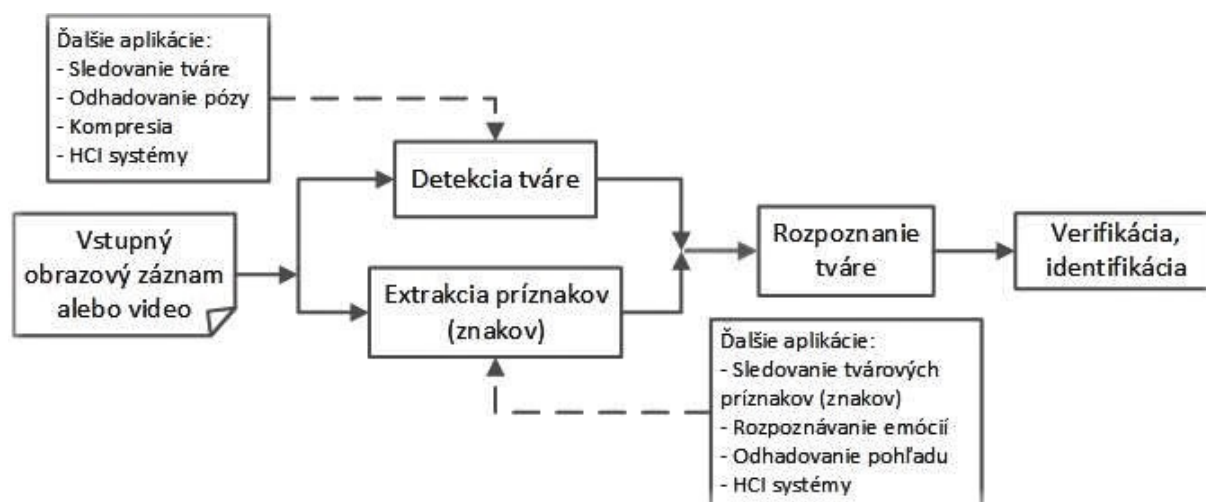


Obrázok 1 – Využitie rozpoznávania v kamerových záznamoch [11]

Základný, zjednodušený proces rozpoznávania tvárí vieme rozdeliť do dvoch krokov, kde najskôr je poskytnutý obrazový záznam alebo video ako vstup a následne je identifikovaná alebo verifikovaná jedna či viac osôb na základe porovnania so záznamami z databázy tvárí. Presnosť identifikácie či verifikácie môžu zvýšiť detaily rozpoznávania ako rasa, pohlavie, vek a iné.

Ak sa na tento problém pozrieme detailnejšie, tak proces (popísaný na Obrázok 2) zahŕňa výber tvárí z obrazu (detekcia), následne extrakciu príznačkov (emócie, pohľad, oči, ústa, nos, tvárové znaky, a iné), rozpoznanie tváre a verifikáciu. Kroky výberu tváre a extrakcie príznačkov sú realizované

pomocou špeciálnych algoritmov, ktoré rozpoznávajú ľudskú tvár na obraze, jej príznaky, črty, prípadne iné požiadavky. Spracované podľa [1].



Obrázok 2 – Proces rozpoznávania tváre [1]

Pre ľudí je rozpoznávanie tvárí bežným a relatívne jednoduchým úkonom. Pri počítačovej technike to je zložitejšie. Problém je najmä vtom, že dodnes presne nevieme ako naše vedomie rozpoznáva ostatných ľudí. Môžeme len odhadovať, ktoré príznaky sú pre nás dôležitejšie a ako sa náš mozog rozhoduje. Do určitej miery však vedci dokázali, že náš mozog pomocou špeciálnych nervových buniek dokáže rozoznať konkrétne príznaky (znaky) nejakej scenérie, ako sú čiarové kontúry, rohy, uhly, pohyb a iné. Nakoľko tieto príznaky nevnímame samostatne, tak vyplýva že naše vedomie tieto príznaky nejakým spôsobom spája dohromady za účelom vytvorenia alebo odhadu istej šablóny (schémy) toho, na čo sa pozeráme.


Z týchto teórií a predpokladov vychádza automatizované rozpoznávanie tvárí pomocou techniky, ktoré sa zakladá na extrakcii významných príznakov obrazu (reprezentácie objektu) a klasifikácii daného objektu (v danom prípade osoby). Informácie z [3].

Možným spôsobom k rozpoznávaniu je rozpoznávanie na základe geometrických vlastností (geometrické body na Obrázok 3). Jedny z prvých rozpoznávacích systémov využívali metódu určovania jednotlivých bodov tváre (pozícia očí, nosa, uší, ...), z ktorých sa utvárali vektory vlastností ako uhly tvorené medzi bodmi, vzdialenosti medzi bodmi, pravidelnosti a iné. Rozpoznávanie bolo počítané pomocou matematických operácií nad týmito vektormi pre vzorový a rozpoznávaný obraz a následne boli oba nad týmito operáciami porovnané.

Metóda bola výhodnou najmä vďaka tomu, že odolávala nepriaznivým vlastnostiam ako napríklad osvetleniu obrazu a iným rušivým vplyvom. Napriek tomu, jej veľkou slabinou bola zložitosť



presného určovania jednotlivých bodov tváre a to aj napriek kvalitným algoritmom. Informácie čerpané z [4].



Obrázok 3 – Geometrické body tváre [12]

Veľkým prínosom bolo uvedenie metódy Eigenfaces, ktorú v roku 1991 popísali Matthew Turk a Alex Pentland (dostupné na [5]). Tá využíva matematickú metódu, ktorá analyzuje hlavné komponenty obrazu (Principal Component Analysis - PCA) a zahŕňa dva základné kroky. V prvom kroku je vytvorený priestor príznakov ako vektor a vytvárajú sa vzory. V druhom kroku je vstupný obraz premietnutý do tohto priestoru a následne je klasifikovaný. Čerpané z [5].

Nakoľko ani metóda Eigenfaces s pomocou PCA nebola bezchybná, vývoj pokračoval. Novším riešením bola metóda Fisherfaces, ktorá nahradila metódu PCA metódou Linear Discriminant Analysis (LDA), ktorá navyše zohľadňuje triedne delenie príznakov. Metóda LDA priamo vychádza z metódy Fisher's Linear Discriminant (FLD), ktorú popísal Sir Ronald Fisher. Informácie z [3].

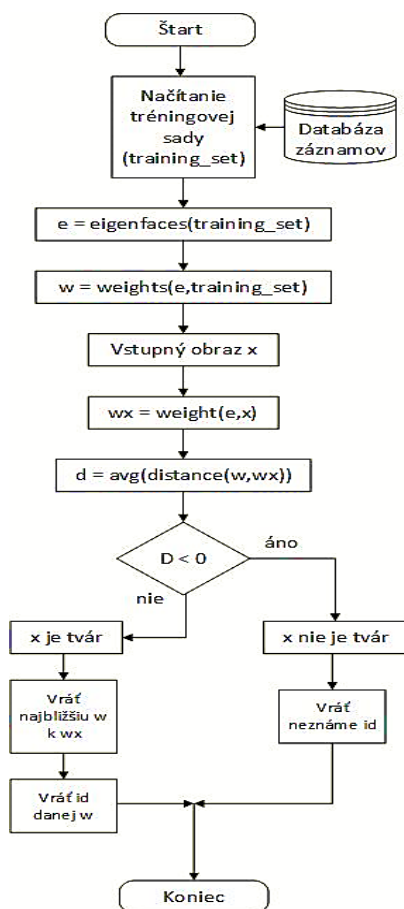
Medzičasom sa objavili metódy zamerané na extrakciu lokálnych príznakov, ktoré boli odolnejšie voči vplyvom ako osvetlenie, malé rozlíšenie záznamu a podobne. Medzi metódy využívané na extrakciu lokálnych príznakov patrí napríklad metóda Local Binary Patterns (LBP) uvedená v [4].

## 2.1 Rozdelenie metód rozpoznávania tváří

Všeobecne môžeme rozdeliť metódy rozpoznávania tváří do troch kategórií: metódy holistického prístupu, príznakovo-orientované metódy a hybridné metódy. Prevzaté z [6].

Holistický (celostný) prístup v zásade využíva celú oblasť tváre ako vstupné dáta, použité v procese rozpoznávania. Najbežnejšími metódami holistického prístupu sú napríklad metódy Eigenfaces a Fisherfaces, využívajúce metód PCA, LDA a ďalšie.

Príklad fungovania holistickej metódy sa dá predviesť napríklad na metóde Eigenfaces. Tá rozdeľuje rozpoznávanie do dvojdimenzionálneho problému. Prvou úlohou v celom procese je vložiť sadu obrazových záznamov do databázy, ktoré sa v rozpoznávači budú načítavať ako tréningová sada a takisto následne využívať pri tvorbe záznamov zvaných eigenfaces. Vstupné záznamy obrazu sú normalizované s ohnivením na oči a ústa. Následne sú zväčšené prípadne zmenšené tak, aby sa ich veľkosť rovnala a mohla byť vykonaná extrakcia záznamov eigenfaces pomocou matematickej metódy PCA. Po vytvorení záznamov eigenfaces, je každý vstupný obraz z databázy reprezentovaný vektorom váh (weights). Systém prijíma vstupný obraz k rozpoznaniu. Zistí váhu vstupného obrazu a porovná ju s váhami obsiahnutými vo vektore. Ak je váha vstupného obrazu väčšia ako vstupná hodnota prahu (threshold), tak systém vráti tvár ako neidentifikovanú. Naopak ak je váha v rozpätí, tak vyhľadá vo vektore najbližšiu váhu k nej príslušnú a vráti identifikačnú hodnotu obrazu z databázy s touto váhou. Výstupom je teda odhadovaná zhoda, respektíve nezhoda vstupného obrazu s obrazovým záznamom z databázy (Obrázok 4 popisuje tento proces). Viac v [6].



Obrázok 4 – Vývojový diagram algoritmu holistickej metódy Eigenfaces [6]

Medzi príznakovo orientované metódy patria tie, ktoré v prvom rade vykonávajú extrakciu lokálnych príznakov ako sú oči, uši, ich umiestnenie a iné. Tieto geometrické údaje následne posielajú do štruktúrneho triediča. Problémy pri týchto metódach nastávajú najmä vo chvíli, keď sú niektoré príznaky nedetekovateľné najmä kvôli uhlu pohľadu, zakrytiu príznaku a podobne.

Príznakovo orientované metódy môžeme bližšie rozdeliť na tri typy:

1. Metódy založené na rozpoznávaní hrán, obrysov, čiar a iných kontúr
2. Metódy založené na príznakových šablónach (predlohách)
3. Metódy založené na štruktúrnym porovnávaní

Hybridné metódy využívajú kombináciu predošlých typov metód, to znamená kombinujú holistické a príznakovo-orientované metódy. Bežne sa využívajú v takýchto hybridných metódach najmä 3D obrazy.

Obrazový záznam tváre je zachytený v 3D, čo umožňuje systému rozpoznávať napríklad uhol, tvar, veľkosť príznakov a podobne. Proces týchto metód prechádza v niekoľkých krokoch, kde prebehne najskôr nájdenie tváre, odhad pozície, veľkosti a uhlu hlavy, nasledované meraním jednotlivých kontúr tváre za účelom vytvorenia šablóny tváre, pretvorením šablóny do matematickej podoby a nakoniec porovnávaním získaných dát s existujúcimi predlohami v databáze. Problém v takýchto metódach môžu byť vstupné 2D obrazy, kedy je nutné 3D predlohy nejakým spôsobom upraviť. V dnešnej dobe sa pri hybridných metódach rozoberá najčastejšie práve tento problém.


Významnými odvetviami v rámci rozpoznávania pohlaví sú pre nás metódy holistického prístupu založené na metódach PCA, LDA a príznakovo orientované metódy založené na metóde LBP. Viac informácií o delení a princípe týchto metód je možné nájsť v [6].

## 2.2 Metóda Principal Component Analysis - PCA

Metóda PCA je dodnes široko používaná v technikách rozpoznávania tvárí ako lineárna transformácia a technika klasifikácie dát. PCA využíva vektory, ktoré sú počítané zo vstupnej tréningovej sady obrázkov.

V prvom kroku sa vypočíta akýsi priemerný obrázok, ktorí je od tejto sady odpočítaný za účelom vytvorenia sady dát. Tieto dáta sú následne uložené v matici  $X$ , kde jeden stĺpec predstavuje dáta jedného obrázku. Táto matica násobená jej transponovanou maticou potom predstavuje vzorovú kovariančnú maticu  $Y$  pre tréningovú sadu obrázkov, kde hlavné komponenty tejto matice sú vypočítané pomocou  $R^T(Y^T)R = \Lambda$ , kde (pre metódu Eigenfaces)  $\Lambda$  je diagonálna matica hodnôt eigenvalues a  $R$  je matica ortonormálnych vektorov eigenvectors.


Cieľom metódy PCA je teda maximalizovať rozdiely vstupných dát a redukovať priestor dát obrazu do menšieho pod-priestoru (príkladom Obrázok 5). Informácie o metóde PCA sú dostupné v [5] a [7].



Obrázok 5 – Redukcia priestoru pomocou PCA [13]

## 2.3 Metóda Linear Discriminant Analysis - LDA

Oproti metóde PCA zohľadňuje metóda LDA aj triednu príslušnosť príznakov. Táto metóda sa snaží maximalizovať pomery medzi rozdielnosťami jednotlivých tried a ich podobnosťami (viď Obrázok 6). Týmto je dosiahnuté maximálne oddelenie podobných a rozdielných tried. Metóda vo veľkej závislosti však stále stojí na princípoch metódy PCA.




Obrázok 6 - Rozdielnosť redukcie pomocou LDA oproti redukcii pomocou PCA [14]



V prvom rade sa vypočítajú zo vstupnej sady  $x$ -dimenzionálne priemerné vektory určitých rozdielnych tried. Vypočítajú sa matice rozptylu (rozdielnych tried a podobných). Nasleduje použitie základu z metódy PCA a tým je výpočet hodnôt eigenvectors a odpovedajúcich hodnôt eigenvalues pre matice rozptylu. Znižujú sa hodnoty eigenvalues a vyberá sa  $k$  počet eigenvectors s najväčšími hodnotami eigenvalues za účelom vytvorenia  $d \times k$ -dimenzionálnej matice  $W$ . Táto matica sa použije na vytvorenie nového redukovaného podpriestoru  $Y$ . Informácie popísane v [8].

## 2.4 Metóda Local Binary Patterns - LBP

Metóda LBP pracuje na úrovni menších štruktúr obrazu a radí sa pod príznakovo orientované metódy. LBP operátor získava hodnoty pre každý pixel, tak že zohľadňuje jeho najbližšie susedné pixely (napríklad mriežka  $3 \times 3$ , kde v strede je daný pixel) a porovnáva ich s týmto pixelom. Ak je hodnota suseda menšia ako stredového pixelu, tak je mu nastavená lokálna hodnota 0, v opačnom prípade, ak je hodnota suseda menšia nastaviť hodnotu 1. Hodnoty susedov sú potom zapísané do jednej binárnej hodnoty a tá je následne preformátovaná do decimálneho výstupu (0110001->97). Operácia je prevedená nad každým pixelom obrazu (viď Obrázok 7). Podrobný popis uvedený v [2] alebo [4].



Obrázok 7 – Spracovanie pixelov pomocou metódy LBP [4]


## 2.5 Rozpoznávanie pohlaví v obrazoch a metódy

Pohlavie vieme v obraze určiť pomocou rôznych metód. Metód pre určovanie existuje mnoho a sú založené na viacerých princípoch rozpoznávania (klasifikácie pohlavia). Medzi bežne používané patria napríklad metóda Eigenfaces (využívajúca metódu PCA), Fisherfaces (využívajúca metódu LDA), metódy využívajúce metódu LBP ako napríklad metóda Local Binary Patterns Histograms (LBPH) popísaná v [4], ale aj iné menej známe metódy ako Fusion of facial strips (FFS) popísanej v [15], či Support Vector Machines (SVM) uvedenej v [22] a mnoho ďalších.

Každá z týchto metód má svoje výhody aj nevýhody. Metódy založené na metóde PCA (Eigenfaces) dokážu vynikajúco zmenšovať objem dát bez straty informácií a sú relatívne veľmi presné, naopak ich úspešnosť klesá pri obrazoch s veľkými rušivými vplyvmi ako sú svetlo, gestá tváre, ale aj pri väčšom množstve vstupných dát.

Naopak v tomto dokážu byť úspešnejšie metódy založené na LBP, ktoré sú voči rušivým vplyvom imúnnejšie a nie sú nimi tak silno ovplyvňované.

Metódy ako napríklad FFS sú ovplyvnené presnosťou a veľkosťou vstupného obrazu. FFS vlastne rozkladá celý obraz na viacero vertikálnych a horizontálnych pásov, pričom následne urobí rozpoznávanie pre jednotlivé pásy (Obrázok 8). V princípe tak vytvára jednotlivé segmentované časti ľudskej tváre a tie vyhodnocuje buď s podobnosťou k mužskej alebo k ženskej časti tváre. Výsledky jednotlivých segmentov metóda na konci spojí a vyhodnotí výsledné určenie pohlavia. Problém nastáva práve vtedy, keď vstupný obraz nie je kompletná tvár alebo je istým spôsobom modifikovaný (napríklad uhol snímania tváre, jej tvar, a iné). Viac informácií o FFS na [15].



Obrázok 8 – Normalizácia a segmentácia tváre pomocou metódy FFS [15]

Veľmi kvalitných výsledkov v oblasti rozpoznávania pohlaví dosahuje najmä metóda Fisherfaces. Fisherfaces sa snaží poukázať na problémy metódy Eigenfaces a snaží sa ich eliminovať. Metóda PCA, ktorú využíva metóda Eigenfaces, hľadá lineárnu kombináciu príznakov, s najväčšou variabilitou. To je síce dobrý spôsob reprezentácie dát, ale nezohľadňuje žiadne triedne delenie a veľa informácií môže byť stratených pri zahadzovaní niektorých komponentov, ktoré sa vyhodnotia ako menej potrebné. Práve tento problém rieši metóda LDA obsiahnutá v metóde Fisherfaces a to tak, že vykonáva triedne-špecifikovanú (class-specific) redukciiu dát a snaží sa zväčšiť pomer rozdielností a podobností jednotlivých tried. Metódy a ich rozdiely sú podrobne popísané v [3].

## 2.6 Metóda Eigenfaces

Jedným z problémov každej reprezentácie obrazu je veľká dimenzionalita (rozsah). Majme napríklad dvojdimenzionálny obrázok 100x100 pixelov. Veľkosť dimenziálneho rozsahu je teda 10000, čo už je dosť veľké číslo na tak malý vstupný obraz. Otázkou však je, či je celý tento rozsah potrebný. Naším cieľom je nejako tento rozsah zmenšiť na redukovaný pod-obsah.

Metóda PCA, ktorá je jadrom Eigenfaces, toto umožňuje a to na základe variability (rozdielností, respektíve podobností) dát, tak že hľadáme len hlavné komponenty, ktoré sú pre reprezentáciu najdôležitejšie. PCA sa teda snaží premeniť nejakú množinu potenciálne podobných premenných na menšiu množinu rozdielných premenných. Myšlienka sa opiera o to, že dáta s veľkým rozsahom sú popísané podobnými premennými, z čoho vyplýva že iba určitá časť komponentov je pre reprezentáciu dôležitou. Metóda PCA teda v skratke hľadá čo najväčšiu rozdielnosť v dátach a reprezentuje súčasti, ktoré nazývame hlavné komponenty. Podrobnejší prehľad v [5] a [3].

### Algoritmus – prevzaté podľa [9]

Majme vektor  $X$ , pre ktorí platí:

$$X = \{x_1, x_2, x_3, \dots, x_n\}; \quad x_i \in \mathbb{R}$$

1. Vypočíta sa stredná hodnota (priemerný obraz):

$$\mu = \frac{1}{n} \sum_{i=1}^n x_i$$

2. Vypočíta sa kovariančná matica  $Y$ :

$$Y = \frac{1}{n} \sum_{i=1}^n (x_i - \mu)(x_i - \mu)^T$$

3. Výpočet hodnôt eigenvalues  $\Lambda_i$  a vektorov eigenvectors  $v_i$  z kovariančnej matice  $Y$ :

$$Yv_i = \Lambda_i v_i, \quad i = 1, 2, 3, \dots, n$$

4. Zoradenie vektorov eigenvectors zostupne podľa hodnoty eigenvalue. Počet hlavných komponentov  $k$  sú eigenvectors súhlasné s  $k$  najväčšími hodnotami eigenvalues.

Počet hlavných komponentov  $k$  daného vektora  $x$  je daný:


$$z = W^T(x - \mu); \quad W = (v_1, v_2, v_3, \dots, v_k)$$

Rekonštrukcia z PCA je daná:

$$x = Wz + \mu; \quad W = (v_1, v_2, v_3, \dots, v_k)$$

Rozpoznanie je prevedené v krokoch tak, že:

1. Všetky obrazy tréningovej sady sú prevedené do priestoru PCA (príklad Obrázok 9)
2. Vstupný obraz určený na rozpoznanie je prevedený do priestoru PCA.
3. Je nájdený najbližší sused z tréningovej sady k vstupnému obrazu.



Obrázok 9 – Príklad eigenfaces vytvorených pod AT&T Laboratories Cambridge [16]

## 2.7 Metóda Fisherfaces

Metóda LDA, ktorá je hlavným jadrom metódy Fisherfaces, pracuje s myšlienkou redukcie dimenzionality na základe triednej špecifikácie (na rozdiel od metódy PCA). Zmysel metódy spočíva v maximalizovaní pomeru rozptylu medzi rozdielnymi a podobnými triedami, na rozdiel od metódy PCA, kde je maximalizovaný celkový rozptyl. To zjednodušene znamená, že rovnaké triedy by mali byť združované viac k sebe a naopak rozdielne triedy by mali byť čo najvzdialenejšie od seba ako to je len možné. Takéto spracovanie problematiky vie riešiť niektoré typy problémov, ako je svetlo, tieň a podobne, efektívnejšie ako metóda PCA. Vďaka triednej špecifikácii je pre rozpoznávanie pohlaví vhodnejšie LDA, čo však tiež môže závisieť od veľkosti a počtu dát tréningovej sady a vstupného obrazu. Viac informácií o LDA nájdeme v [3] alebo [8].



### Algoritmus – prevzaté podľa [9]

Majme vektor  $X$ , so záznamami z  $k$  tried, pre ktoré platí:

$$X = \{X_1, X_2, X_3, \dots, X_k\}$$

$$X_i = \{x_1, x_2, x_3, \dots, x_n\}$$

1. Vypočíta sa celková stredná hodnota  $\mu$ :

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i$$

2. Vypočíta sa stredná hodnota  $\mu_i$  danej triedy  $i \in \{1, 2, \dots, k\}$ :

$$\mu_i = \frac{1}{|X_i|} \sum_{x_j \in X_i} x_j$$

3. Vypočítajú sa matice rozptylu  $Y_B$  a  $Y_W$ :

$$Y_B = \sum_{i=1}^k N_i (\mu_i - \mu)(\mu_i - \mu)^T$$
$$Y_W = \sum_{i=1}^k \sum_{x_j \in X_i} (x_j - \mu_i)(x_j - \mu_i)^T$$

4. Následne sa hľadá projekcia  $W$ , ktorá maximalizuje oddelenie rozdielnych tried:

$$W_{opt} = \arg \max_W \frac{|W^T Y_B W|}{|W^T Y_W W|}$$


Obrázok 10 uvádza príklad vytvorených fisherfaces. Kvôli niektorým problémom, ktoré pri redukcii vznikajú je možné upraviť algoritmus tak, že je najskôr prevedená PCA redukcia a nad týmito dátami je následne prevedené LDA redukcia. Problém optimalizácie môže byť následne zapísaný takto:

$$W_{pca} = \arg \max_W |W^T Y_T W|$$
$$W_{lda} = \arg \max_W \frac{|W^T W_{pca}^T Y_B W_{pca} W|}{|W^T W_{pca}^T Y_W W_{pca} W|}$$

, kde  $W_{pca}$  predstavuje maticu pre spracované PCA a  $W_{lda}$  predstavuje maticu pre LDA.

Transformačná matica  $W$ , ktorá prevádza záznam do  $(k - 1)$ -dimenzionálneho rozsahu je potom definovaná ako:

$$W = W_{lda}^T W_{pca}^T$$



Obrázok 10 – Príklad výstupu spracovaných záznamov Fisherfaces [17]

## 2.8 Metóda Local Binary Patterns Histograms

Metódy Eigenfaces a Fisherfaces sú silnými zástupcami holistických metód ale svoje miesto v rozpoznávaní majú aj štrukturálne metódy. Pri rozpoznávaní v bežných podmienkach nemôžeme očakávať ideálne vstupné dáta. Nemôžeme očakávať ideálne osvetlenie na obraze ani ideálne záznamy osôb a tým pádom by bolo rozpoznávanie pomocou holistických metód skutočne veľmi nepresné, nakoľko sú voči rušivým vplyvom menej odolné. Práve toto je oblasť, kde dokážu vyniknúť štrukturálne metódy ako je práve LBPH metóda (s využitím LBP metódy) popísaná v [4].

Myšlienkou takéhoto rozpoznávania je popísať jednotlivé lokálne príznaky objektu, na rozdiel od holistických metód, ktoré popisujú celý obraz ako viac-dimenzionálny vektor. Takto extrahované príznaky majú samozrejme menšiu dimenzionalitu (rozsah).

LBP metóda má za cieľ utvárať lokálne štruktúry v obraze pomocou porovnávania jednotlivých pixelov s ich najbližšími susedmi.

Majme určitý pixel umiestnený v strede rozsahu 3x3 pixely, kde ostatné pixely predstavujú jeho susedov. Ak je intenzita stredného pixelu väčšia alebo rovná voči susednému pixelu, tak pre daný stredový pixel sused predstavuje hodnotu 1, v opačnom prípade predstavuje hodnotu 0. Z týchto hodnôt sa zostaví výsledná binárna hodnota, napríklad 01101110. Takáto hodnota je vytvorená pre každý pixel obrazu a z konvenčných dôvodov je prevedená do decimálnej hodnoty. Takéto spracovanie potom nazývame Local Binary Patterns (lokálne binárne šablóny).

Takto reprezentovaný obraz je rozdelený do niekoľkých lokálnych oblastí a pre každú takúto oblasť je vyextrahovaný histogram. Zreťazením týchto lokálnych histogramov je následne vytvorený vektor príznakov.

Tieto histogramy nazývame pojmom Local Binary Patterns Histograms (histogramy lokálnych binárnych šablón). Popísané podľa [4].


### Algoritmus – prevzaté podľa [9]

LBP operátor môžeme definovať nasledovne:

$$LBP(x_c, y_c) = \sum_{p=0}^{P-1} 2^p s(i_p - i_c)$$

, kde  $(x_c, y_c)$  predstavujú stredový pixel,  $i_c$  intenzitu stredového pixelu,  $i_p$  intenzitu susedného pixelu a  $s(x)$  je funkcia, ktorá ak je  $x \geq 0$  vráti hodnotu 1, alebo v opačnom prípade hodnotu 0.

S ohľadom na detaily v rôznej veľkosti je v dnešnej dobe operátor rozšírený k používaniu variabilných susedstiev (Extended LBP – Obrázok 11). Cieľom je zoskupiť ľubovoľný počet susedov na kruhu s variabilným polomerom (rádus)  $R$ . Ďalším možným rozšírením je napríklad metóda MB-LBP popísaná v [2].




Obrázok 11 – Princíp variability susedstiev v Extended LBP,  $R$  – rádus [18]

Pozícia suseda  $(x_p, y_p)$ , kde  $p \in P$  k určitému stredovému pixelu  $(x_c, y_c)$  je vypočítaná ako:

$$x_p = x_c + R \cos\left(\frac{2\pi p}{P}\right)$$

$$y_p = y_c + R \sin\left(\frac{2\pi p}{P}\right)$$


LBP reprezentácia obrazu je rozdelená do  $k$  lokálnych oblastí a prebieha extrahovanie histogramov. Následne vzniká vektor  $H$  vytvorený zrežaním histogramov (postup – Obrázok 12).



Vstupný obraz



LBP obraz



LBP Histogram

Obrázok 12 – Spracovanie obrazu pomocou LBP a výstupný histogram [19]

### 3 Vlastná implementácia a testovanie

Pre implementáciu vlastných riešení je ideálnym nástrojom knižnica OpenCV, ktorá je vedená pod BSD licenciou a je voľne dostupná na akademické a komerčné účely. Softvérová knižnica OpenCV je zameraná najmä na spracovanie obrazu a počítačovo-učiace sa nástroje.

Knižnica obsahuje mnohé algoritmy od jednoduchého spracovania až po zložité. Zároveň zahŕňa práve metódy určené na detekciu tvárí, pohlaví a podobne. OpenCV bola vyvinutá a navrhnutá ako cross-platform a ponúka teda vývoj pod viacerými platformami a pomocou rôznych programovacích jazykov. Podrobný prehľad možností knižnice na [10].

Pre potreby návrhu vlastného rozpoznávacieho algoritmu využijeme jazyk C++ a vývojové prostredie Microsoft Visual Studio 2015 najmä kvôli dobrej kompatibilite a ideálnej manipulácii pre dané riešenie.

Hlavnou úlohou vlastnej implementácie a praktického testovania je porovnať metódy Eigenfaces, Fisherfaces a LBPH nad rôznymi vstupnými sádami a zhodnotiť výsledky týchto pozorovaní.

#### 3.1 Príprava dát a implementácia

Knižnica OpenCV poskytuje triedu FaceRecognizer, ktorá v sebe zahŕňa metódy pre vytvorenie rozpoznávača Eigenfaces, Fisherfaces alebo LBPH a zároveň poskytuje metódy pre manipuláciu s týmto rozpoznávačom.

Pre funkčné rozpoznávanie budeme v prvom rade potrebovať vzorovú tréningovú sadu pomocou, ktorej sa daný rozpoznávač bude učiť. Takúto sadu môžeme vytvoriť sami, alebo použiť niektorú z dostupných predpripravených sád, ktoré sú voľne dostupné na internete. Za predpokladu, že vytvárame vlastnú sadu je potrebné obrázky upraviť tak, aby bola tvár na obraze správne orezaná, otočená a obraz mal správnu veľkosť s dôrazom na pozíciu príznakov tváre ako oči, nos, ústa a podobne.

Pre naše potreby testovania je vhodné využiť niektorú z existujúcich voľne dostupných sád. Na testovanie využijeme sady AT&T Laboratories-Cambridge (dostupná na [23]) a Extended Yale Face Database B (dostupná na [24]). Databázy obsahujú niekoľko tvárí zachytených v rôznych uhloch, gestách ale aj obrazy obsahujúce rušivé vplyvy ako napríklad intenzita svetla v obraze a podobne.

Je predpokladom, že sada AT&T obsahuje jednoduché dáta a YaleB obsahuje presnejšie a väčšie množstvo dát. Sady sú štruktúrované do priečinkov tak, že každá osoba má vlastný priečinok obsahujúci rôzny počet obrazových záznamov tejto osoby. Majme sadu desiatich osôb, kde pre každú túto osobu existuje desať obrazových záznamov vo formáte PGM.



Hierarchia sady teda bude vyzerat' nasledovne:

```
./sada/osoba1/obraz1.pgm
...
./sada/osoba1/obraz10.pgm
./sada/osoba2/obraz1.pgm
...
./sada/osoba10/obraz10.pgm
```

Rozdelenie sady obrázkov do priečinkov podľa osôb je pre určenie pohlavie zanedbateľné. Hierarchie upravíme do takej podoby, kde je jasné že priečinok osoby pripadá konkrétnemu pohlaviu. Modifikujme priečinky tak, že každý priečinok ženskej osoby je označený písmenom F a priečinok mužskej osoby písmenom M. Nová hierarchia môže byť štruktúrovaná nasledovne:

```
./sada/F_osoba1/obraz1.pgm
...
./sada/F_osoba1/obraz10.pgm
./sada/F_osoba2/obraz1.pgm
...
./sada/M_osoba10/obraz10.pgm
```

Jednoduchý Python skript, vytvorený podľa [9], nám následne zaručí vytvorenie CSV súboru (vstup sady v programe) s odkazmi na jednotlivé obrazy tak, že riadok je formulovaný ako cesta s označením pohlavia nasledovne:

```
..\sada\F_osoba1/obraz1.pgm; 0
...
..\sada\M_osoba10/obraz10.pgm; 1
```

, kde hodnota 0 alebo 1 za oddeľovačom udáva pohlavie na danom obraze (0 – žena, 1- muž). Obrazy v programe budeme reprezentovať premennou typu `vector<Mat>` a ich príslušnosť k pohlaviu premennou typu `vector<int>`, kde každá pozícia vo vektore obrazov odpovedá každej pozícii vo vektore príslušností k pohlaviu. Zo súboru CSV je čítaná najskôr cesta, kde obraz k nej príslušný je následne pomocou metódy `imread` (metóda OpenCV), pridaný do vektoru obrazov a v druhom rade je čítaná príslušnosť, ktorá je následne pridaná do vektoru príslušností.

Takto pripravené dáta môžeme následne použiť na vytvorenie modelu rozpoznávača. Na to nám v OpenCV slúži objekt typu `Ptr<FaceRecognizer>`, ktorí konštruujeme pomocou jednej z metód

`createEigenFaceRecognizer()`, `createFisherFaceRecognizer()` alebo `createLBPHFaceRecognizer()`, v závislosti na použitej metóde rozpoznávania. Pomocou metódy pre trénovanie, zahrnutej v objekte rozpoznávača, následne natrénujeme rozpoznávač pre dané vektory obrazov a ich príslušností k pohlaviu.


Ak je vytvorený model rozpoznávača, je následne potrebné istým spôsobom tváre na obrazoch hľadať a extrahovať ich ako samostatný obraz k porovnaniu. K tomu nám bude slúžiť špeciálny kaskádový klasifikátor. OpenCV nám ich ponúka hneď niekoľko, pre rozpoznávanie rôznych objektov, akými sú aj ľudské tváre. Rozdeliť ich môžeme do niekoľkých skupín, pričom pre rozpoznávanie tvárí sú najpoužívanejšími skupinami HaarCascade klasifikátory a LBPCascade klasifikátory. Obe skupiny majú svoje výhody aj nevýhody. Haar sú v niektorých situáciách presnejšie, ale bohužiaľ vyžadujú veľa času na spracovanie obrazu. Naopak LBP klasifikátory sú rýchle a robustné, ale ich presnosť môže byť niekedy o niečo málo slabšia ako u Haar. Pre potreby nášho praktického testovania a porovnania použijeme dva klasifikátory, kde jeden patrí do skupiny Haar a druhý do skupiny LBP. Zo skupiny Haar volíme klasifikátor `frontalface_default` a zo skupiny LBP volíme klasifikátor `frontalface`.

Poslednou prípravnou operáciou pred samotnou detekciou je pred-spracovanie (pre-processing) vstupného obrazu určeného k detekcii. Spracovanie pred detekciou vyžaduje minimálne normalizáciu obrazu do čiernobielych odtieňov farby. Ideálne je vytvoriť si kópiu obrazu, nad ktorou sú spracovanie a detekcia prevedené a výsledky po detekcii spätne vrátiť do pôvodného obrazu.

Po takomto pred-spracovaní obrazu je možné začať detekciu. Tá začína vyhľadávaním tvárí pomocou kaskádového klasifikátora. Vyhľadávanie nám umožní metóda `detectMultiScale`, ktorá prehľadáva vstupný obraz a nájdené umiestnenia tvárí ukladá do výstupného vektoru. Zároveň umožňuje manipuláciu so spôsobom prechádzania obrazu a detekciou tvárí.

Manipuláciu umožňujú vstupné parametre `scaleFactor`, `minNeighbors`, `minSize` a `maxSize` tejto funkcie. Pri hľadaní tvárí sa obsah obrazu prechádza v určitej veľkosti rozsahu pixelov a pri detekcii tváre navracia túto aktuálnu pozíciu. Po prejdení je táto veľkosť škálovaná parametrom `scaleFactor` a nastáva ďalšie prechádzanie obrazu. Hodnotu `scaleFactor` môžeme nastaviť na vlastnú hodnotu, čím môžeme dosiahnuť rýchlejšie, či presnejšie prechádzanie obrazu a odstránenie niektorých chybných detekcií tvárí. S tým je úzko spätý ďalší parameter a to `minNeighbors`. Pri hľadaní tváre sa stane, že niektorú tvár detekujeme pri postupných prechodoch viackrát. Aby nedochádzalo k rovnakej detekcii jednej tváre, je možné nastaviť parameter `minNeighbors` na takú hodnotu, ktorá bude dve blízke detekcie považovať za jednu detekovanú tvár, nie za dve, či viac. V poslednom rade parametre `minSize` a `maxSize` definujú minimálnu a maximálnu veľkosť takého objektu, ktorý sa pokladá za správnu detekciu. Objekty, ktorých veľkosť je menšia ako `minSize` alebo väčšia ako `maxSize` sú automaticky ignorované.

Správnym nastavením parametrov funkcie `detectMultiScale` vieme eliminovať mnohé chyby a zrýchliť proces vyhľadávania tvárí. Je preto nesmierne dôležité testovať vhodné hodnoty parametrov tejto metódy, za účelom zvýšenia efektívnosti detekcie tvárí v obraze.



Obrázok 13 – Výsledok nesprávnych nastavení v metóde `detectMultiScale`

Výstupný vektor detekovaných tvárí môžeme následne otestovať na rozpoznávanie pohlaví. Vektor postupne prechádzame cyklom pričom každý ďalší obraz vektora prejde najskôr predzpracovaním (pre-processing) a v tomto stave sa zapíše do kópie obrazu. Pri metódach `Eigenfaces` a `Fisherfaces` je následne potrebné túto kópiu veľkostne normalizovať na takú veľkosť, aká odpovedá veľkosti obrazov v tréningovej sade. Nad modelom rozpoznávača voláme metódu `predict`, kde vstupným parametrom je normalizovaná kópia vstupného obrazu a návratová hodnota je číslo predpokladaného pohlavia z vektora príslušností pohlaví (0 – žena, 1 – muž).

Výstupom po ukončení cyklu nám môže byť počet tvárí a rozpoznané pohlavia osôb, či grafické znázornenie detekcie a odhad pohlavia ako nový obraz. Pri grafickom výstupe vkladáme výsledky do pôvodného obrazu, ktorý následne vykreslíme pomocou metódy `imshow` alebo zapíšeme do nového súboru metódou `imwrite`.

Špeciálnym prípadom je rozpoznávanie tvárí v reálnom čase na video vstupe. Namiesto vstupného obrazu vytvárame inštanciu triedy `VideoCapture`, kde v konštrukte je vstupným parametrom id zariadenia (štandardne použité zariadenie má id 0). Vytvárame následne cyklus, ktorý pri každej iterácii vyberie zachytenú snímku a uloží ju do premennej, ktorá predstavuje vstupný obraz k rozpoznávaniu. Následne prebieha rovnaké spracovanie, detekcia, rozpoznávanie a vykreslenie ako pri rozpoznávaní na statickom obraze.

## 3.2 Testovanie a vstupy

Funkčnosť navrhnutých algoritmov budeme testovať pre jednotlivé metódy Eigenfaces, Fisherfaces a LBPH vo všetkých takých prípadoch, kedy:

1. Využívame jednu z dvoch tréningových sád
2. Používame Haar alebo LBP klasifikátor

Pre každú z metód získame teda viacero meraní, kde percentuálnu úspešnosť metódy budeme hodnotiť ako počet správne rozpoznaných pohlaví vzhľadom na počet detekovaných tvárí. Pri statickom obraze je vhodné voliť testovací obraz s väčším počtom tvárí a to z dôvodu presnejšieho výpočtu úspešnosti danej metódy. Ak by sme volili obraz s menším počtom tvárí, výsledky by mohli byť skreslené a posúdené ako relevantné voči reálnej úspešnosti danej metódy.

Majme nasledujúce statické obrazy označené ako Test1 a Test2:



Obrázok 14 – Vstupný obraz k rozpoznávaniu, priaznivé podmienky, Test1 [20]



Obrázok 15 – Vstupný obraz k rozpoznávaniu, nepriaznivé podmienky, Test2 [21]

Tieto obrazy budú figurovať ako vstupy k rozpoznávaniu. Následne majme dve vstupné tréningové sady, kde prvá menšia sada obsahuje záznamy štyroch mužov a štyroch žien z databázy AT&T (označme ako Sada1) a druhá rozsiahlejšia sada obsahuje záznamy šiestich mužov a šiestich žien z databázy YaleB (označme ako Sada2). Na základe daných vstupov prevedieme testovanie pre metódy Eigenfaces, Fisherfaces a LBPH. Parametre metódy detectMultiScale ponecháme nastavené v nasledujúcich hodnotách:


Tabuľka 1 – Hodnoty parametrov metódy detectMultiScale pre testovanie

scaleFactor	1.1
minNeighbors	3
minSize	cv:Size()
maxSize	cv:Size()


Metódy a vstupné obrazy (Test1, Test2) testujeme najskôr nad tréningovou Sadou1 a následne nad tréningovou Sadou2. Výsledky percentuálnych úspešností sú prevedené pre oba testovacie obrazy a pre každý je testované pod LBP a Haar klasifikátormi. Dostávame tak osem hodnôt pre každú z metód. Pre porovnanie vykreslíme percentuálne úspešnosti do grafov.

### 3.3 Výsledky testovania Eigenfaces

Testovaním boli získané nasledujúce výsledky percentuálnej úspešnosti metódy Eigenfaces (%):



Obrázok 16 – Percentuálna úspešnosť metódy Eigenfaces pre vstupné testovacie obrazy (Test1, Test2), tréningová Sada1




Obrázok 17 – Percentuálna úspešnosť metódy Eigenfaces pre vstupné testovacie obrazy (Test1, Test2), tréningová Sada2

Z výsledkov môžeme usúdiť, že pri malej sade dát k učeniu je metóda obstojná, najmä ak je vstupný obraz ideálne čistý a bez rušivých vplyvov. Pri prvom testovacom obraze sa hodnoty nezmenili ani po zmene vstupnej sady, z čoho vyplýva, že úspešnosť metódy nie je daná množstvom dát tréningovej sady, ale naopak je daná kvalitou dát tréningovej sady, čo sa prejavilo pri testovaní druhého obrazu nad databázou YaleFacesB.


Z pomedzi klasifikátorov sa osvedčilo LBP, ktoré v danom prípade vykazovalo nulovú chybovosť detekcie. Pri spracovaní obrazov bol takisto priemerný čas klasifikácie LBP výrazne nižší ako čas Haar klasifikácie. Ideálnym použitím pri metóde Eigenfaces by pravdepodobne bola stredne veľká tréningová sada a klasifikátor LBP.

### 3.4 Výsledky testovania Fisherfaces

Získané výsledky percentuálnej úspešností metódy Fisherfaces (%):



Obrázok 18 – Percentuálna úspešnosť metódy Fisherfaces pre vstupné testovacie obrazy (Test1, Test2), tréningová Sada1




Obrázok 19 – Percentuálna úspešnosť metódy Fisherfaces pre vstupné testovacie obrazy (Test1, Test2), tréningová Sada2

Výsledky naznačujú, že metóda Fisherfaces priniesla výrazne zlepšenie výsledkov oproti metóde Eigenfaces. Pri tréningovej Sade1 nastalo zlepšenie pri rozpoznávaní druhého vstupného obrazu, čo naznačuje väčšiu odolnosť voči nepriaznivým vplyvom ako metóda Eigenfaces. Výrazne zlepšenie prinieslo ako väčšie množstvo, tak aj lepšia kvalita vstupných záznamov Sady2. U klasifikátorov bolo opäť lepším riešením pre metódu Fisherfaces použiť LBP.

Môžeme usúdiť, že optimálnym riešením pre metódu Fisherfaces by mohla byť väčšia tréningová sada a klasifikátor LBP, pričom podobne ako pri Eigenfaces, tak aj Fisherfaces metóda je dosť citlivá na rušivé vplyvy.


### 3.5 Výsledky testovania Local Binary Patterns Histograms

Výsledky percentuálnej úspešnosti (%):



Obrázok 20 – Percentuálna úspešnosť metódy LBPH pre vstupné testovacie obrazy (Test1, Test2), tréningová Sada1





Obrázok 21 – Percentuálna úspešnosť metódy LBPH pre vstupné testovacie obrazy (Test1, Test2), tréningová Sada2

Výsledky testovania poukázali na skutočnosť, že metóda LBPH podobne ako metóda Fisherfaces, je založená na kvalitnej a optimálnej veľkej sade tréningových dát. Narozdiel od predošlých metód však LBPH prekonáva ostatné svojou rýchlosťou a to či už za použitia LBP alebo Haar klasifikátora. Kým učenie a spracovanie pri metódach Fisherfaces a Eigenfaces prebehne niekedy v rádoch stoviek sekúnd, u LBPH je to až takmer desať-krát menej. Príčinou je však najmä to, že metóda nevyžaduje veľkostné úpravy obrazu, takže doba spracovania sa rapídne skráti.

LBPH môže byť optimálnym riešením pri rozpoznávaní v obrazoch s často nepriaznivými a rušivými vplyvmi, najmä kvôli svojej rýchlosti a robustnosti.

### 3.6 Zhodnotenie výsledkov

V testoch, pre testovací obraz Test1 sa najviac osvedčila metóda Fisherfaces, ktorej úspešnosť dosahovala najvyššej úrovne 76,74% za použitia klasifikátora LBP a vstupnej tréningovej Sady2 (výstup na Obrázku 22). Metóda však vyžaduje veľkú vstupnú sadu a spracováva sa v relatívne dlhšom čase ako ostatné.

V testoch, pre testovací obraz Test2 sa najviac osvedčila metóda LBPH s najvyššou úspešnosťou 55,88% za použitia LBP klasifikátora a vstupnej tréningovej Sady2 (výstup na Obrázku 23). Metóda dosiahla najvyššej úspešnosti a zároveň najrýchlejšieho spracovania v čase, kvôli čomu sa pre daný obraz Test2 javí ako najefektívnejšia.

Metóda Eigenfaces sa ukázala ako priemerne efektívna, ale narozdiel od ostatných dvoch metód jej výsledky nie sú vždy ovplyvnené veľkosťou vstupnej sady, preto sa dá predpokladať, že metóda si vystačí aj s malou tréningovou sadou.

Ako vhodný klasifikátor sa celkovo ukázal klasifikátor skupiny LBP. Nielenže bol relatívne presný, ale oproti klasifikátoru Haar aj o určitú dobu spracovania rýchlejší.

Efektívnejšou tréningovou sadou sa zo zistených výsledkov zdá byť Sada2 vytvorená nad databázou YaleB. Jej dáta sú mohutnejšie a presnejšie, čo sa odzrkadlilo na výsledkoch.



Obrázok 22 – Výstup metódy Fisherfaces pre testovací obraz Test1, klasifikátor LBP, tréningová Sada2 (oranžová – žena, modrá – muž)



Obrázok 23 – Výstup metódy LBPH pre testovací obraz Test2, klasifikátor LBP, tréningová Sada2 (oranžová – žena, modrá – muž)

Nastavenie parametrov metódy detectMultiScale sa podľa dosiahnutých výsledkov zdá byť vhodné pre testovanie na vstupných obrazoch Test1, Test2. Možným vylepšením výsledkov by mohlo byť kombinovanie metód Eigenfaces, Fisherfaces a LBPH, či testovanie na objemnejších a presnejších tréningových sadách dát.

## 4 Záver

Práca popísala základné pojmy a metódy v oblasti rozpoznávania tváří a pohlaví. Teoretické poznatky boli riadne zdokumentované tak, aby čitateľovi priblížili problematiku tejto oblasti a zároveň uviedli bežne využívané metódy, či už z hľadiska matematického spracovania alebo stručného popisu algoritmizácie jednotlivých metód.

Praktickou časťou implementácie a testovania boli potvrdené predpoklady funkcionality jednotlivých metód vo viacerých podmienkach pre rozličné testovacie dáta. Výsledky poukázali na možnosti použitia týchto metód, ich prednosti a náchylnosti. Práca čitateľovi ďalej ponúka možnosť využitia v roli určitého základu a oboznámenia pri vlastnej realizácii v oblasti rozpoznávania tváří a pohlaví.

Práca dosiahla stanovených cieľov z hľadiska spracovania teoretickej časti, implementácie, testovania a zhodnotenia reálnych záverov. Takisto priblížila stručné poznatky v oblasti práce so softvérovou knižnicou OpenCV a možnosťami jej využitia pre danú problematiku.

Rozpoznávanie tváří a pohlaví je oblasť výskumu, ktorá sa v dnešnej dobe veľmi rýchlo rozširuje a dokáže pomôcť v mnohých oblastiach. Bohužiaľ neexistuje jednoznačný návod ako správne vytvoriť kvalitný rozpoznávací systém a takisto nie je možné jednoducho povedať, ktorá metóda spracovania je najvhodnejšia. Jediným možným spôsobom vytvorenia kvalitného rozpoznávacieho systému je veľké množstvo testovaní a hromadenia výsledkov. Zatiaľ môžeme len predpokladať ako proces rozpoznávania funguje u nás ľudí a preto táto oblasť stále ponúka množstvo teórií ako zabezpečiť dokonalé, automatizované rozpoznávanie v obrazoch.

Testovacie výsledky práce vykazujú, že metódy rozpoznávania môžu byť omylné a vždy je možné určitým spôsobom ich vylepšiť. Oblasť rozpoznávania nám ponúka mnoho metód a spôsobov, ktorými je možné zvýšiť úspešnosť detekcie, či už je to manipulácia s niektorými vstupnými parametrami, použitie rozličných metód pre rozpoznanie, ich kombinovanie alebo kvalita vstupných dát.

Práca sa snaží na toto poukázať. Do budúca ponúka možnosť aplikovania vylepšení a použitia nových spôsobov, či metód za účelom zvýšenia efektívnosti detekcie tváří a rozpoznávania pohlaví v obrazoch.

# Literatúra

- [1] ZHAO, W., R. CHELLAPPA, P. J. PHILLIPS a A. ROSENFELD. Face recognition. *ACM Computing Surveys* [online]. 2003, **35**(4), 399-458 [cit. 2017-03-04].  
Dostupné z: <http://portal.acm.org/citation.cfm?doid=954339.954342>
- [2] LIAO, Shengcai, Xiangxin ZHU, Zhen LEI, Lun ZHANG a Stan Z. LI. Learning Multi-scale Block Local Binary Patterns for Face Recognition. *Advances in Biometrics* [online]. Berlin, Heidelberg: Springer Berlin Heidelberg, 2007, s. 828 [cit. 2017-03-04].  
Dostupné z: [http://link.springer.com/10.1007/978-3-540-74549-5\\_87](http://link.springer.com/10.1007/978-3-540-74549-5_87)
- [3] BELHUMEUR, P.N., J.P. HESPANHA a D.J. KRIEGMAN. Eigenfaces vs. Fisherfaces: recognition using class specific linear projection. *IEEE Transactions on Pattern Analysis and Machine Intelligence* [online]. **19**(7), 711-720 [cit. 2017-03-04].  
Dostupné z: <http://ieeexplore.ieee.org/document/598228/>
- [4] AHONEN, Timo, Abdenour HADID a Matti PIETIKÄINEN. *Face Recognition with Local Binary Patterns* [online]. s. 469-481 [cit. 2017-03-04].  
Dostupné z: [http://link.springer.com/10.1007/978-3-540-24670-1\\_36](http://link.springer.com/10.1007/978-3-540-24670-1_36)
- [5] TURK, M.A. a A.P. PENTLAND. Face recognition using eigenfaces. In: *Proceedings. 1991 IEEE Computer Society Conference on Computer Vision and Pattern Recognition* [online]. IEEE Comput. Soc. Press, 1991, s. 586-591 [cit. 2017-03-07].  
Dostupné z: <http://ieeexplore.ieee.org/document/139758/>
- [6] PARMAR, Divyarajsinh N.; MEHTA, Brijesh B. Face recognition methods & applications. *arXiv preprint arXiv:1403.0485*, 2014. [cit. 2017-03-07]
- [7] DRAPER, Bruce A., Kyungim BAEK, Marian Stewart BARTLETT a J.Ross BEVERIDGE. Recognizing faces with PCA and ICA. *Computer Vision and Image Understanding* [online]. 2003, **91**(1-2), 115-137 [cit. 2017-04-25].  
Dostupné z: <http://linkinghub.elsevier.com/retrieve/pii/S1077314203000778>
- [8] BALAKRISHNAMA, Suresh; GANAPATHIRAJU, Aravind. Linear discriminant analysis-a brief tutorial. *Institute for Signal and information Processing*, 1998, 18.
- [9] WAGNER, Philipp. Face recognition with python. *Tersedia dalam: www. bytefish. de [diakses pada 16 Februari 2015]*, 2012.
- [10] BRADSKI, Gary; KAEHLER, Adrian. *Learning OpenCV: Computer vision with the OpenCV library*. " O'Reilly Media, Inc.", 2008.
- [11] B. KELLEY, Michael. The FBI's Nationwide Facial Recognition System Ends Anonymity As We Know It. In: *Business Insider* [online]. 2012 [cit. 2017-04-03].  
Dostupné z: <http://www.businessinsider.com/the-fbis-nationwide-facial-recognition-system-2012-9>

- [12] DAVID, Kravets. Smile, you're in the FBI face-recognition database. In: *Ars Technica* [online]. 2016 [cit. 2017-04-03]. Dostupné z: <https://arstechnica.com/tech-policy/2016/06/smile-youre-in-the-fbi-face-recognition-database/>
- [13] G. WALTERS, Austin. PCA: Principal Component Analysis. In: *Austin G. Walters* [online]. 2014 [cit. 2017-03-17]. Dostupné z: <http://austingwalters.com/pca-principal-component-analysis/>
- [14] A., Stephen a Hongbing HU. Nonlinear Dimensionality Reduction Methods for Use with Automatic Speech Recognition. *Speech Technologies* [online]. InTech, 2011 [cit. 2017-03-15]. Dostupné z: <http://www.intechopen.com/books/speech-technologies/nonlinear-dimensionality-reduction-methods-for-use-with-automatic-speech-recognition>
- [15] LEE, Ping-Han; HUNG, Jui-Yu; HUNG, Yi-Ping. Automatic gender recognition using fusion of facial strips. In: *Pattern recognition (ICPR), 2010 20th international conference on*. IEEE, 2010. p. 1140-1143.
- [16] Eigenface. In: *Wikipedia: the free encyclopedia* [online]. San Francisco (CA): Wikimedia Foundation, 2017 [cit. 2017-03-15]. Dostupné z: <https://en.wikipedia.org/wiki/Eigenface>
- [17] T. SMITH, Nicholas. Eigenfaces versus Fisherfaces on the Faces94 Database with Scikit-Learn. In: *Nicholastsmith: The personal website and blog of Nicholas T. Smith*. [online]. 2016 [cit. 2017-04-25]. Dostupné z: <https://nicholastsmith.wordpress.com/2016/02/18/eigenfaces-versus-fisherfaces-on-the-faces94-database-with-scikit-learn/>
- [18] ZHAO, Xiaoming a Shiqing ZHANG. Facial Expression Recognition Based on Local Binary Patterns and Kernel Discriminant Isomap. *Sensors* [online]. 2011, **11**(12), 9573-9588 [cit. 2017-04-25]. Dostupné z: <http://www.mdpi.com/1424-8220/11/10/9573/>
- [19] SADEGH M.SC, Reihaneh. Researches: Facial expression recognition using appearance-based statistical method. In: *Reihaneh Sadegh, M.SC: Yazd University* [online]. 2014 [cit. 2017-04-24]. Dostupné z: <https://pws.yazd.ac.ir/rezaeian/Sadegh/researches.html>
- [20] AHKÂM. Group PNG. In: *Free Icons PNG* [online]. [cit. 2017-04-21]. Dostupné z: <http://www.freeiconspng.com/free-images/group-png-3219>
- [21] MEREDITH, Shiner. Mourning turns to cheers. In: *Politico: The Global Politico* [online]. 2011 [cit. 2017-04-21]. Dostupné z: <http://www.politico.com/story/2011/01/mourning-turns-to-cheers-047538>
- [22] TONG, Simon a Edward CHANG. Support vector machine active learning for image retrieval. In: *Proceedings of the ninth ACM international conference on Multimedia - MULTIMEDIA '01* [online]. New York, New York, USA: ACM Press, 2001, s. 107-118 [cit. 2017-03-07]. Dostupné z: <http://portal.acm.org/citation.cfm?doid=500141.500159>
- [23] The Database of Faces. AT&T Laboratories Cambridge [online]. © 2002 [cit. 2017-03-04]. Dostupné z: <http://www.cl.cam.ac.uk/research/dtg/attarchive/facedatabase.html>

[24] The Extended Yale Face Database B. [online]. [cit. 2017-03-04]

Dostupné z: <http://vision.ucsd.edu/~leekc/ExtYaleDatabase/ExtYaleB.html>